



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ  
CAMPUS TERESINA CENTRAL  
CURSO TECNOLOGIA EM RADIOLOGIA**

**LUANA MAGALHÃES PEREIRA**

**AVALIAÇÃO DA EFETIVIDADE DA INTELIGÊNCIA ARTIFICIAL NO  
DIAGNÓSTICO IMEDIATO DE PATOLOGIAS TORÁCICAS EM RADIOGRAFIAS  
DE URGÊNCIA: revisão integrativa da literatura**

**TERESINA  
2025**

LUANA MAGALHÃES PEREIRA

AVALIAÇÃO DA EFETIVIDADE DA INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO  
IMEDIATO DE PATOLOGIAS TORÁCICAS EM RADIOGRAFIAS DE  
URGÊNCIA: revisão integrativa da literatura

Trabalho de Conclusão de Curso  
(artigo científico) apresentado como  
exigência parcial para obtenção do  
diploma do Curso de Tecnologia em  
Radiologia do Instituto Federal de  
Educação, Ciência e Tecnologia do  
Piauí, Campus Teresina Central.

Orientador: Prof. Dr. Ednaldo  
Francisco Santos Oliveira Junior.

TERESINA

2025

# **AVALIAÇÃO DA EFETIVIDADE DA INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO IMEDIATO DE PATOLOGIAS TORÁCICAS EM RADIOGRAFIAS DE URGÊNCIA: revisão Integrativa da Literatura**

Luana Magalhães Pereira<sup>1</sup>  
Ednaldo Francisco Santos Oliveira Junior<sup>2</sup>

## **RESUMO**

Considerando o problema da demora na interpretação de radiografias de tórax em contextos de urgência, sobretudo diante da escassez de radiologistas, este estudo justifica-se pela necessidade de ferramentas capazes de otimizar o diagnóstico e aprimorar a tomada de decisão clínica. Objetiva-se avaliar a efetividade da Inteligência Artificial (IA), em especial dos algoritmos de *deep learning*, no diagnóstico imediato de patologias torácicas em radiografias de urgência. Para tanto, procede-se a uma revisão integrativa da literatura, realizada entre agosto e setembro de 2025, nas bases Google Scholar, PubMed, LILACS e SciELO, incluindo estudos publicados nos últimos cinco anos que abordam o uso de IA na detecção de pneumotórax, insuficiência cardíaca, pneumonia e tuberculose. Desse modo, observa-se que os modelos de *deep learning* alcançam sensibilidade e especificidade médias superiores a 90%, com desempenho comparável ao de radiologistas experientes e significativa redução no tempo de triagem, o que reforça seu potencial clínico como ferramenta de apoio diagnóstico. Isso permite concluir que a aplicação da IA em radiografias de tórax representa um avanço relevante para a radiologia de urgência, contribuindo para diagnósticos mais rápidos, precisos e acessíveis, embora ainda demande padronização metodológica e validação multicêntrica para garantir sua integração segura à prática médica.

**Palavras-chave:** radiografia de tórax, aprendizado profundo, urgência, inteligência artificial.

## **ABSTRACT**

Considering the problem of delayed interpretation of chest radiographs in emergency settings, especially due to the shortage of radiologists, this study is justified by the need for tools capable of optimizing diagnosis and improving clinical decision-making. The objective is to evaluate the effectiveness of Artificial Intelligence (AI), particularly deep learning algorithms, in the immediate diagnosis of thoracic pathologies on emergency chest radiographs. To this end, an integrative literature review was conducted between August and September 2025 using the Google Scholar, PubMed, LILACS, and SciELO databases, including studies published in the last five years that address the use of AI in detecting pneumothorax, heart failure, pneumonia, and tuberculosis. Thus, it was observed that deep learning models achieve average sensitivity and specificity above 90%, with performance comparable to that of experienced radiologists and a significant reduction in triage time, reinforcing their clinical potential as diagnostic support tools. This allows us to

---

<sup>1</sup> Graduanda em Tecnologia em Radiologia. Instituto Federal do Piauí. [luanamglhx@gmail.com](mailto:luanamglhx@gmail.com).

<sup>2</sup> Doutor em Ciências da Saúde. Instituto Federal do Piauí. [edinaldojunior@ifpi.edu.br](mailto:edinaldojunior@ifpi.edu.br).

conclude that the application of AI in chest radiography represents a relevant advance for emergency radiology, contributing to faster, more accurate, and accessible diagnoses, although methodological standardization and multicenter validation are still required to ensure its safe integration into medical practice

**Keywords:** chest X-ray, deep learning, emergency, artificial intelligence.

Data de aprovação: 15/12/2025

## 1 INTRODUÇÃO

A Inteligência Artificial (IA), em especial seu subcampo de *deep learning*, tem se consolidado como uma tecnologia promissora para a análise e interpretação de exames por imagem, oferecendo a capacidade de reconhecer padrões complexos e processar grandes volumes de dados de forma automatizada. Estudos de revisão e metanálises demonstram que algoritmos de aprendizagem profunda alcançam, em diversas tarefas de diagnóstico por imagem, acurácias comparáveis às de especialistas humanos, tornando-se, assim, uma ferramenta potencialmente transformadora para triagem, detecção precoce e quantificação de achados radiológicos (Aggarwal *et al.*, 2021).

Na literatura, já se encontram aplicações consolidadas e resultados animadores em diferentes áreas, como na oftalmologia, com a detecção da retinopatia diabética, na radiologia torácica, com a identificação de pneumonias e nódulos pulmonares, e na mamografia, com a detecção de lesões suspeitas. Tais estudos apresentam valores elevados de acurácia, sensibilidade e especificidade em cenários controlados. Contudo, também revelam limitações importantes, como a heterogeneidade metodológica entre as pesquisas, a ausência de validação externa em muitos casos e a carência de ensaios clínicos que avaliem o impacto real da IA na prática médica e nos desfechos clínicos dos pacientes (Aggarwal *et al.*, 2021); (Mello-thoms, Mello, 2023).

Apesar dos avanços, desafios significativos ainda precisam ser enfrentados para que a IA seja plenamente integrada ao uso clínico. Entre eles, destacam-se os vieses nos conjuntos de dados — relacionados à representatividade demográfica e tecnológica —, a rotulagem imprecisa, a dependência excessiva de *benchmarks* públicos que não refletem a complexidade do ambiente hospitalar, além da dificuldade de transparência nos algoritmos, muitas vezes descritos como verdadeiras “caixas-pretas”. Diante disso, especialistas defendem a necessidade de maior rigor metodológico, com validação externa multicêntrica, documentação detalhada dos

dados, estudos de impacto clínico e implementação de práticas de explicabilidade. Do mesmo modo, políticas e regulações adequadas são fundamentais para garantir a segurança, a equidade e a eficácia dessas tecnologias em ambientes de cuidado real (Varoquaux, Cheplygina, 2022); (Mello-thoms, Mello, 2023); (Gonçalves *et al.*, 2024).

Nesse cenário, a radiografia de tórax assume um papel de destaque, sendo um dos exames mais solicitados em diferentes níveis de atenção à saúde. Sua ampla disponibilidade, baixo custo e rapidez de execução tornam-na um recurso indispensável, sobretudo em atendimentos de urgência e emergência. Trata-se de um método não invasivo, utilizado rotineiramente na investigação de sintomas como dispneia, dor torácica e febre persistente, além de ter aplicação em avaliações pré-operatórias (Brasil, 2022); (Silva, Souza, 2021).

A radiografia de tórax é capaz de revelar alterações relacionadas a uma ampla variedade de patologias, incluindo pneumonias, tuberculose, neoplasias pulmonares, derrames pleurais, pneumotórax e cardiopatias como a cardiomegalia e a insuficiência cardíaca congestiva (Fleischner Society, 2020). Para que esses achados sejam identificados com precisão, é necessário não apenas conhecimento anatômico detalhado e análise sistemática das projeções — geralmente posteroanterior e perfil —, mas também a correlação com dados clínicos e laboratoriais, o que reforça a complexidade do processo diagnóstico (Khalil *et al.*, 2019); (Pinho *et al.*, 2020).

Diante disso, o objetivo deste artigo é explorar o uso da Inteligência Artificial como ferramenta de apoio na análise de radiografias de tórax em ambientes de urgência. Busca-se demonstrar como essa tecnologia pode contribuir para a detecção rápida de condições críticas, como pneumonia bacteriana e pneumonia causada por Covid 19, pneumotórax, insuficiência cardíaca aguda e tuberculose, sem substituir o trabalho do médico radiologista, mas sim oferecendo um recurso complementar. A intenção é destacar o potencial da IA para agilizar diagnósticos e aumentar a segurança clínica, especialmente em contextos nos quais cada minuto pode influenciar diretamente no desfecho do paciente.

## **2 METODOLOGIA**

A metodologia adotada neste estudo baseia-se na revisão integrativa da literatura. De acordo com (Ocaña-fernández, Fuster-guillén, 2021), a revisão bibliográfica caracteriza-se por ser uma metodologia sistemática e retrospectiva, cujo propósito é selecionar, interpretar e discutir criticamente produções científicas a fim de reunir informações pertinentes ao tema pesquisado. Foram usadas como banco de dados as bibliotecas online.

O estudo foi desenvolvido por meio de uma revisão bibliográfica integrativa e crítica, realizada entre agosto e setembro de 2025, utilizando as bases Google Scholar, PubMed, LILACS e SciELO. Na presente pesquisa, a estratégia metodológica adotada consistiu na utilização de uma busca estruturada em bases científicas, aplicando simultaneamente os descritores “deep learning” OR “artificial intelligence” AND “chest X-ray”, para encontrar artigos em língua inglesa e os descritores “aprendizado profundo” OR “inteligência artificial” AND “radiografia de tórax”, para encontrar artigos em língua portuguesa e “aprendizaje profundo” OR “inteligência artificial” AND “radiografia de tórax” em língua espanhola, todos estes diretamente na barra de pesquisa das bases consultadas.

Foram incluídos artigos publicados nos últimos cinco anos, em português, espanhol e inglês, selecionados a partir de descritores relacionados à inteligência artificial aplicada à análise de radiografias de tórax em contextos de emergência. A triagem ocorreu inicialmente por títulos e resumos, seguida da leitura completa dos textos elegíveis.

Os critérios de inclusão contemplaram artigos originais, estudos de validação clínica, revisões sistemáticas e trabalhos de meta-análise que abordassem o uso de inteligência artificial (*machine learning*, *deep learning*, redes neurais, entre outros) em cenários de emergência e que citem as patologias torácicas citadas na introdução.

Já os critérios de exclusão eliminaram estudos que não envolviam diretamente radiografias de tórax, trabalhos sem metodologia clara em IA, duplicados, sem acesso gratuito ou com temas repetidos.

Quadro 1 – Número de artigos identificados antes e depois da triagem, organizados de acordo com os termos de busca aplicados, os filtros selecionados e as bases de dados consultadas.

| GOOGLE SCHOLAR                                                                                                                                        | PUBMED                                                                                                                                            | LILACS                                                                                                                                           | SCIELO                                                                                                                                           |
|-------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------|
| Descritores em inglês: "deep learning" OR "artificial intelligence" AND "chest X-ray"<br><br>Número de artigos Encontrados: 25.200<br>Após triagem: 7 | Descritores em inglês: "deep learning" OR "artificial intelligence" AND "chest X-ray"<br><br>Número de artigos Encontrados: 27<br>Após triagem: 6 | Descritores em inglês: "deep learning" OR "artificial intelligence" AND "chest X-ray"<br><br>Número de artigos Encontrados: 1<br>Após triagem: 0 | Descritores em inglês: "deep learning" OR "artificial intelligence" AND "chest X-ray"<br><br>Número de artigos Encontrados: 0<br>Após triagem: 0 |
| Descritores em português: "aprendizado                                                                                                                | Descritores em português: "aprendizado                                                                                                            | Descritores em português: "aprendizado                                                                                                           | Descritores em português: "aprendizado                                                                                                           |

|                                                                                                                      |                                                                                                                            |                                                                                                                            |                                                                                                                            |
|----------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------|
| profundo" OR<br>"inteligência artificial"<br>AND "radiografia de<br>tórax"                                           | profundo" OR<br>"inteligência artificial"<br>AND "radiografia de<br>tórax"                                                 | profundo" OR<br>"inteligência artificial"<br>AND "radiografia de<br>tórax"                                                 | profundo" OR<br>"inteligência artificial"<br>AND "radiografia de<br>tórax"                                                 |
| Número de artigos<br>Encontrados: 116<br>Após triagem: 0                                                             | Número de artigos<br>Encontrados: 0<br>Após triagem: 0                                                                     | Número de artigos<br>Encontrados: 0<br>Após triagem: 0                                                                     | Número de artigos<br>Encontrados: 0<br>Após triagem: 0                                                                     |
| Descritores espanhol:<br>"aprendizaje<br>profundo" OR<br>"inteligência artificial"<br>AND " radiografia de<br>tórax" | Descritores em<br>espanhol:<br>"aprendizaje<br>profundo" OR<br>"inteligência artificial"<br>AND " radiografia de<br>tórax" | Descritores em<br>espanhol:<br>"aprendizaje<br>profundo" OR<br>"inteligência artificial"<br>AND " radiografia de<br>tórax" | Descritores em<br>espanhol:<br>"aprendizaje<br>profundo" OR<br>"inteligência<br>artificial" AND "<br>radiografia de tórax" |
| Número de artigos<br>Encontrados: 655<br>Após triagem: 0                                                             | Número de artigos<br>Encontrados: 0<br>Após triagem: 0                                                                     | Número de artigos<br>Encontrados: 2<br>Após triagem: 0                                                                     | Número de artigos<br>Encontrados: 0<br>Após triagem: 0                                                                     |
| <b>TOTAL: 13</b>                                                                                                     |                                                                                                                            |                                                                                                                            |                                                                                                                            |

Fonte: Desenvolvido pelos autores, 2025.

### 3 RESULTADOS

Quadro 2 – Artigos usados para a revisão separados por título, autores, ano de publicação, objetivo e a revista em que foram publicados.

| nº | Título Original                                                                                                              | Autores                   | Ano  | Revista                                      |
|----|------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|----------------------------------------------|
| 1  | Deep Learning for Pneumothorax Detection on Chest Radiograph: A Diagnostic Test Accuracy Systematic Review and Meta Analysis | Katzman <i>et al.</i>     | 2024 | Canadian Association of Radiologists Journal |
| 2  | Deep learning for pneumothorax diagnosis: a systematic review and meta-analysis                                              | Sugibayashi <i>et al.</i> | 2023 | European Respiratory Society                 |
| 3  | Evaluation of an Artificial Intelligence Model for Detection of Pneumothorax and Tension Pneumothorax in Chest               | Hillis <i>et al.</i>      | 2022 | JAMA Network Open                            |

|   |                                                                                                                                                                         |                           |      |                                      |
|---|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|--------------------------------------|
|   | Radiographs                                                                                                                                                             |                           |      |                                      |
| 4 | Deep learning approach for analyzing chest X-rays to predict cardiac events in heart failure                                                                            | Kusunose <i>et al.</i>    | 2023 | Frontiers in Cardiovascular Medicine |
| 5 | Early Detection of Heart Failure with Autonomous AI-Based Model Using Chest Radiographs: A Multicenter Study                                                            | Garza-frias <i>et al.</i> | 2024 | MDPI                                 |
| 6 | Inteligência Artificial Aplicada à Radiografia de Tórax: Uma Ferramenta Confiável para Avaliar o Diagnóstico Diferencial de Pneumonia Pulmonar no Serviço de Emergência | Ippolito <i>et al.</i>    | 2023 | MDPI                                 |
| 7 | Machine and Deep Learning for Tuberculosis Detection on Chest X-Radiographs: Systematic Literature Review                                                               | Hansun <i>et al.</i>      | 2023 | Journal of Medical Internet Research |
| 8 | Chest X-ray Analysis With Deep Learning-Based Software as a Triage Test for Pulmonary Tuberculosis: An Individual Patient Data Meta-Analysis of Diagnostic Accuracy     | Tavaziva <i>et al.</i>    | 2022 | Oxford Academic                      |
| 9 | Weakly-supervised localization of radiographic manifestations in pulmonary tuberculosis from chest X-                                                                   | Feyisa <i>et al.</i>      | 2023 | MDPI                                 |



|    |                                                                                                                                          |                       |      |                            |
|----|------------------------------------------------------------------------------------------------------------------------------------------|-----------------------|------|----------------------------|
|    | rays: a systematic review                                                                                                                |                       |      |                            |
| 10 | A Systematic Review of Deep Learning Techniques for Tuberculosis Detection From Chest Radiograph                                         | Oloko-oba; Viriri     | 2022 | Frontiers in Public Health |
| 11 | An artificial intelligence deep learning platform achieves high diagnostic accuracy for Covid-19 pneumonia by reading chest X-ray images | Li, D; Li, S          | 2022 | iScience                   |
| 12 | Artificial intelligence-assisted chest X-ray for the diagnosis of COVID-19: a systematic review and meta-analysis                        | Tzeng <i>et al.</i>   | 2023 | MDPI                       |
| 13 | Development and prospective validation of the COVID-19 chest X-ray triage model for patients presenting to emergency departments         | Drozдов <i>et al.</i> | 2021 | Scientific Reports         |

Fonte: Desenvolvido pelos autores, 2025

Quadro 3 – Resultados dos estudos sobre o desempenho de algoritmos de aprendizado profundo em radiografias de tórax

| nº | Autor/Ano                    | Amostra                                   | Objetivo                                                                                       | Principais Resultados Numéricos (Quando apresentado)                                       | Conclusões Principais                                     |
|----|------------------------------|-------------------------------------------|------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------|-----------------------------------------------------------|
| 1  | Katzman <i>et al.</i> (2024) | Meta-análise de estudos sobre pneumotórax | Avaliar a precisão de algoritmos de deep learning para detecção de pneumotórax em radiografias | Sensibilidade 87% (IC 95%: 81–92%); Especificidade 95% (IC 95%: 92–97%); AUC 0,97 (IC 95%: | DL apresentou desempenho excelente e baixo risco de viés. |

|   |                                  |                                                         |                                                                                                              |                                                                                  |                                                                    |
|---|----------------------------------|---------------------------------------------------------|--------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------|--------------------------------------------------------------------|
|   |                                  |                                                         | torácicas.                                                                                                   | 0,95–0,98)                                                                       |                                                                    |
| 2 | Sugibayashi <i>et al.</i> (2023) | 32 estudos (diversas modalidades)                       | Revisar o desempenho diagnóstico de modelos de aprendizado profundo aplicados à detecção de pneumotórax.     | Sens. 84% (IC 95%: 79–89%); Esp. 96% (IC 95%: 94–98%); AUC 0,97                  | Desempenho comparável a especialistas; 57% com alto risco de viés. |
| 3 | Hillis <i>et al.</i> (2022)      | 985 radiografias; idade média 60,8 anos; 44,3% mulheres | Validar o desempenho de IA na detecção de pneumotórax e pneumotórax hipertensivo.                            | AUC 0,979; sens. 94,3%; esp. 92,0%; hipertensivo: AUC 0,987                      | IA com alta acurácia, especialmente em pneumotórax hipertensivo.   |
| 4 | Kusunose <i>et al.</i> (2023)    | Pacientes com insuficiência cardíaca                    | Aplicar deep learning em radiografias para prever eventos cardíacos em pacientes com insuficiência cardíaca. | AUC = 0,80; sensibilidade = 0,77; especificidade = 0,74; acurácia preditiva alta | IA identificou padrões de remodelamento e congestão pulmonar.      |
| 5 | Garza-frias <i>et al.</i> (2024) | 1.117 radiografias; 630 mulheres; 487 homens            | Desenvolver e validar modelo autônomo baseado em IA para diagnóstico precoce de insuficiência cardíaca.      | AUC 0,798; Sens. 0,813; Esp. 0,684; Acurácia 0,732                               | Modelo robusto entre sexos e grupos de fração de ejeção.           |
| 6 | Ippolito <i>et al.</i> (2023)    | 2.140 COVID-19; 1.500 pneumonia                         | Analisar o uso de IA em radiografias de tórax para diagnóstico diferencial de pneumonia                      | COVID-19: sens. 94,7%, esp. 80,2%; Pneumonia: sens. 97,5%, esp. 83,9%            | IA com concordância quase perfeita ( $\kappa = 0,822–0,913$ ).     |
| 7 | Hansun <i>et al.</i> (2023)      | Revisão sistemática                                     | Revisar técnicas de machine learning e deep learning na detecção de tuberculose pulmonar.                    | Acurácia 0,83–0,99; Sens. 0,78–0,97; Esp. 0,80–0,98                              | Modelos VGG-16, ResNet e DenseNet com alta robustez diagnóstica.   |
| 8 | Tavaziva <i>et al.</i> (2022)    | 3.727 participantes; 17% PVHA; 17% TB confirmada        | Avaliar softwares de deep learning para triagem de tuberculose em radiografias de tórax.                     | Sens. 90%; Esp. CAD4TBv6 56,9%; Lunit 54,1%; qXRv2 60,5%                         | IA com desempenho semelhante ao de leitores humanos.               |

|    |                             |                                                       |                                                                                                                                                                                                                                                                          |                                                                                   |                                                                                                                   |
|----|-----------------------------|-------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------|
| 9  | Feyisa <i>et al.</i> (2023) | Revisão sistemática de estudos sobre TB pulmonar      | Compreender como os algoritmos de deep learning podem melhorar a localização e a interpretação automatizada de achados radiográficos em TBP, contribuindo para diagnósticos mais precisos e para o suporte à decisão clínica.                                            | Acurácia média dos modelos acima de 90% em detecção de TB em CXR                  | DL mostrou alto potencial para identificar padrões sutis e melhorar a explicabilidade na detecção de TB pulmonar. |
| 10 | Oloko-oba; Viriri (2022)    | 62 estudos incluídos em revisão sistemática           | Revisar sistematicamente e as técnicas de deep learning utilizadas na detecção da tuberculose pulmonar em radiografias de tórax, avaliando seu desempenho, bases de dados empregadas e limitações atuais dos estudos.                                                    | Acurácia variando de 85% a 98%, AUC até 0,99                                      | DL apresentou resultados promissores, mas há necessidade de padronização e validação externa dos modelos.         |
| 11 | Li, D; Li, S (2022)         | 13.000 radiografias (COVID-19, pneumonia e saudáveis) | Desenvolver e validar uma plataforma de inteligência artificial baseada em deep learning capaz de diagnosticar pneumonia por Covid-19 em radiografias de tórax com alta precisão, distinguindo-a de outras formas de pneumonia viral, bacteriana e de pulmões saudáveis. | Acurácia = 97,4%; sensibilidade = 96,3%; especificidade = 98,1%                   | IA diferenciou COVID-19 de outras pneumonias com alta precisão e desempenho comparável ao de radiologistas.       |
| 12 | Tzeng <i>et al.</i> (2023)  | Meta-análise de estudos com IA aplicada à COVID-19    | Avaliar a precisão diagnóstica de IA na detecção de COVID-19 em radiografias                                                                                                                                                                                             | Sensibilidade combinada: 94% (IC95%: 90–96%); especificidade: 93% (IC95%: 89–95%) | IA demonstrou alta acurácia diagnóstica, reforçando seu uso como ferramenta auxiliar no                           |

|    |                             |                                               |                                                                                                                                                |                                                         |                                                                                                                  |
|----|-----------------------------|-----------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------|------------------------------------------------------------------------------------------------------------------|
|    |                             |                                               | de tórax por meio de revisão sistemática e meta-análise.                                                                                       |                                                         | rastreio de COVID-19.                                                                                            |
| 13 | Drozdo <i>et al.</i> (2021) | 1.500 radiografias de pacientes de emergência | Desenvolver e validar o modelo Covlx para detectar pneumonia por COVID-19 em radiografias de tórax com desempenho similar ao de radiologistas. | AUC = 0,95; sensibilidade = 0,89; especificidade = 0,91 | Modelo Covlx apresentou desempenho comparável a radiologistas na triagem automatizada de pneumonia por COVID-19. |

Fonte : Desenvolvido pelos autores, 2025

### 3 DISCUSSÃO

Este estudo procura analisar diferentes fontes de dados que discutam o uso de *deep learning*, inteligência artificial que analisa imagens médicas, para a detecção de algumas patologias que são mais incidentes no serviço de urgência; pneumotórax, insuficiência cardíaca, pneumonia (bacteriana e por Covid 19) e tuberculose.

Inicialmente, a integração dos resultados obtidos nos três estudos — (Katzman *et al.* 2024), (Sugibayashi *et al.* 2023) e (Hillis *et al.* 2022) — demonstra de forma consistente o alto desempenho dos modelos de aprendizado profundo aplicados à detecção automatizada de pneumotórax em radiografias de tórax, consolidando essa abordagem como uma ferramenta diagnóstica complementar de grande potencial clínico. (Katzman *et al.* 2024), em uma meta-análise com 23 estudos e mais de 34 mil exames, observaram sensibilidade combinada de 87% e especificidade de 95%, indicando que os algoritmos são capazes de identificar casos de pneumotórax com acurácia próxima à dos radiologistas experientes, sem impacto significativo de variáveis como desenho do estudo ou origem do banco de dados. Esses resultados dialogam com os achados de (Sugibayashi *et al.* 2023), que, ao analisar 63 estudos e mais de 30 mil radiografias, também encontraram desempenho semelhante entre modelos de *deep learning* e médicos radiologistas, com AUC médio de 0,97 e sensibilidade e especificidade de 84% e 96%, respectivamente. O estudo europeu ainda destacou que, embora o desempenho dos algoritmos seja robusto, a

Quadro 2 – Artigos usados para a revisão separados por título, autores, ano de publicação, objetivo e a revista em que foram publicados.

| nº | Título Original                                                                                                              | Autores                   | Ano  | Revista                                      |
|----|------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|----------------------------------------------|
| 1  | Deep Learning for Pneumothorax Detection on Chest Radiograph: A Diagnostic Test Accuracy Systematic Review and Meta Analysis | Katzman <i>et al.</i>     | 2024 | Canadian Association of Radiologists Journal |
| 2  | Deep learning for pneumothorax diagnosis: a systematic review and meta-analysis                                              | Sugibayashi <i>et al.</i> | 2023 | European Respiratory Society                 |
| 3  | Evaluation of an Artificial Intelligence Model for Detection of Pneumothorax and Tension Pneumothorax in Chest Radiographs   | Hillis <i>et al.</i>      | 2022 | JAMA Network Open                            |
| 4  | Deep learning approach for analyzing chest X-rays to predict cardiac events in heart failure                                 | Kusunose <i>et al.</i>    | 2023 | Frontiers in Cardiovascular Medicine         |
| 5  | Early Detection of Heart Failure with Autonomous AI-Based Model Using Chest Radiographs: A Multicenter Study                 | Garza-frias <i>et al.</i> | 2024 | MDPI                                         |
| 6  | Inteligência Artificial Aplicada à Radiografia de Tórax: Uma Ferramenta Confiável para Avaliar o Diagnóstico Diferencial de  | Ippolito <i>et al.</i>    | 2023 | MDPI                                         |

|    |                                                                                                                                                                     |                        |      |                                      |
|----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------|------|--------------------------------------|
|    | Pneumonia Pulmonar no Serviço de Emergência                                                                                                                         |                        |      |                                      |
| 7  | Machine and Deep Learning for Tuberculosis Detection on Chest X-Radiographs: Systematic Literature Review                                                           | Hansun <i>et al.</i>   | 2023 | Journal of Medical Internet Research |
| 8  | Chest X-ray Analysis With Deep Learning-Based Software as a Triage Test for Pulmonary Tuberculosis: An Individual Patient Data Meta-Analysis of Diagnostic Accuracy | Tavaziva <i>et al.</i> | 2022 | Oxford Academic                      |
| 9  | Weakly-supervised localization of radiographic manifestations in pulmonary tuberculosis from chest X-rays: a systematic review                                      | Feyisa <i>et al.</i>   | 2023 | MDPI                                 |
| 10 | A Systematic Review of Deep Learning Techniques for Tuberculosis Detection From Chest Radiograph                                                                    | Oloko-oba; Viriri      | 2022 | Frontiers in Public Health           |
| 11 | An artificial intelligence deep learning platform achieves high diagnostic accuracy for Covid-19 pneumonia by reading chest X-ray images                            | Li, D; Li, S           | 2022 | iScience                             |
| 12 | Artificial intelligence-assisted chest X-ray for the diagnosis of                                                                                                   | Tzeng <i>et al.</i>    | 2023 | MDPI                                 |

|    |                                                                                                                                  |                      |      |                    |
|----|----------------------------------------------------------------------------------------------------------------------------------|----------------------|------|--------------------|
|    | COVID-19: a systematic review and meta-analysis                                                                                  |                      |      |                    |
| 13 | Development and prospective validation of the COVID-19 chest X-ray triage model for patients presenting to emergency departments | Drozdv <i>et al.</i> | 2021 | Scientific Reports |

Fonte: Desenvolvido pelos autores, 2025

Quadro 3 – Resultados dos estudos sobre o desempenho de algoritmos de aprendizado profundo em radiografias de tórax

| nº | Autor/Ano                        | Amostra                                                 | Objetivo                                                                                                  | Principais Resultados Numéricos (Quando apresentado)                                                  | Conclusões Principais                                              |
|----|----------------------------------|---------------------------------------------------------|-----------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------|
| 1  | Katzman <i>et al.</i> (2024)     | Meta-análise de estudos sobre pneumotórax               | Avaliar a precisão de algoritmos de deep learning para detecção de pneumotórax em radiografias torácicas. | Sensibilidade 87% (IC 95%: 81–92%); Especificidade 95% (IC 95%: 92–97%); AUC 0,97 (IC 95%: 0,95–0,98) | DL apresentou desempenho excelente e baixo risco de viés.          |
| 2  | Sugibayashi <i>et al.</i> (2023) | 32 estudos (diversas modalidades)                       | Revisar o desempenho diagnóstico de modelos de aprendizado profundo aplicados à detecção de pneumotórax.  | Sens. 84% (IC 95%: 79–89%); Esp. 96% (IC 95%: 94–98%); AUC 0,97                                       | Desempenho comparável a especialistas; 57% com alto risco de viés. |
| 3  | Hillis <i>et al.</i> (2022)      | 985 radiografias; idade média 60,8 anos; 44,3% mulheres | Validar o desempenho de IA na detecção de pneumotórax e pneumotórax hipertensivo.                         | AUC 0,979; sens. 94,3%; esp. 92,0%; hipertensivo: AUC 0,987                                           | IA com alta acurácia, especialmente em pneumotórax hipertensivo.   |
| 4  | Kusunose <i>et al.</i> (2023)    | Pacientes com insuficiência cardíaca                    | Aplicar deep learning em radiografias para prever eventos cardíacos em pacientes com insuficiência        | AUC = 0,80; sensibilidade = 0,77; especificidade = 0,74; acurácia preditiva alta                      | IA identificou padrões de remodelamento e congestão pulmonar.      |

|    |                                  |                                                  |                                                                                                                                                                                                                               |                                                                       |                                                                                                                   |
|----|----------------------------------|--------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------|
|    |                                  |                                                  | cardíaca.                                                                                                                                                                                                                     |                                                                       |                                                                                                                   |
| 5  | Garza-frias <i>et al.</i> (2024) | 1.117 radiografias; 630 mulheres; 487 homens     | Desenvolver e validar modelo autônomo baseado em IA para diagnóstico precoce de insuficiência cardíaca.                                                                                                                       | AUC 0,798; Sens. 0,813; Esp. 0,684; Acurácia 0,732                    | Modelo robusto entre sexos e grupos de fração de ejeção.                                                          |
| 6  | Ippolito <i>et al.</i> (2023)    | 2.140 COVID-19; 1.500 pneumonia                  | Analisar o uso de IA em radiografias de tórax para diagnóstico diferencial de pneumonia                                                                                                                                       | COVID-19: sens. 94,7%, esp. 80,2%; Pneumonia: sens. 97,5%, esp. 83,9% | IA com concordância quase perfeita ( $\kappa = 0,822-0,913$ ).                                                    |
| 7  | Hansun <i>et al.</i> (2023)      | Revisão sistemática                              | Revisar técnicas de machine learning e deep learning na detecção de tuberculose pulmonar.                                                                                                                                     | Acurácia 0,83–0,99; Sens. 0,78–0,97; Esp. 0,80–0,98                   | Modelos VGG-16, ResNet e DenseNet com alta robustez diagnóstica.                                                  |
| 8  | Tavaziva <i>et al.</i> (2022)    | 3.727 participantes; 17% PVHA; 17% TB confirmada | Avaliar softwares de deep learning para triagem de tuberculose em radiografias de tórax.                                                                                                                                      | Sens. 90%; Esp. CAD4TBv6 56,9%; Lunit 54,1%; qXRv2 60,5%              | IA com desempenho semelhante ao de leitores humanos.                                                              |
| 9  | Feyisa <i>et al.</i> (2023)      | Revisão sistemática de estudos sobre TB pulmonar | Compreender como os algoritmos de deep learning podem melhorar a localização e a interpretação automatizada de achados radiográficos em TBP, contribuindo para diagnósticos mais precisos e para o suporte à decisão clínica. | Acurácia média dos modelos acima de 90% em detecção de TB em CXR      | DL mostrou alto potencial para identificar padrões sutis e melhorar a explicabilidade na detecção de TB pulmonar. |
| 10 | Oloko-oba; Viriri (2022)         | 62 estudos incluídos em revisão sistemática      | Revisar sistematicamente as técnicas de deep learning utilizadas na detecção da tuberculose pulmonar em radiografias de tórax, avaliando seu                                                                                  | Acurácia variando de 85% a 98%, AUC até 0,99                          | DL apresentou resultados promissores, mas há necessidade de padronização e validação externa dos modelos.         |



|    |                              |                                                       |                                                                                                                                                                                                                                                                          |                                                                                   |                                                                                                                  |
|----|------------------------------|-------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------|
|    |                              |                                                       | desempenho, bases de dados empregadas e limitações atuais dos estudos.                                                                                                                                                                                                   |                                                                                   |                                                                                                                  |
| 11 | Li, D; Li, S (2022)          | 13.000 radiografias (COVID-19, pneumonia e saudáveis) | Desenvolver e validar uma plataforma de inteligência artificial baseada em deep learning capaz de diagnosticar pneumonia por Covid-19 em radiografias de tórax com alta precisão, distinguindo-a de outras formas de pneumonia viral, bacteriana e de pulmões saudáveis. | Acurácia = 97,4%; sensibilidade = 96,3%; especificidade = 98,1%                   | IA diferenciou COVID-19 de outras pneumonias com alta precisão e desempenho comparável ao de radiologistas.      |
| 12 | Tzeng <i>et al.</i> (2023)   | Meta-análise de estudos com IA aplicada à COVID-19    | Avaliar a precisão diagnóstica de IA na detecção de COVID-19 em radiografias de tórax por meio de revisão sistemática e meta-análise.                                                                                                                                    | Sensibilidade combinada: 94% (IC95%: 90–96%); especificidade: 93% (IC95%: 89–95%) | IA demonstrou alta acurácia diagnóstica, reforçando seu uso como ferramenta auxiliar no rastreio de COVID-19.    |
| 13 | Drozдов <i>et al.</i> (2021) | 1.500 radiografias de pacientes de emergência         | Desenvolver e validar o modelo Covlx para detectar pneumonia por COVID-19 em radiografias de tórax com desempenho similar ao de radiologistas.                                                                                                                           | AUC = 0,95; sensibilidade = 0,89; especificidade = 0,91                           | Modelo Covlx apresentou desempenho comparável a radiologistas na triagem automatizada de pneumonia por COVID-19. |

Fonte : Desenvolvido pelos autores, 2025

### 3 DISCUSSÃO

Este estudo procura analisar diferentes fontes de dados que discutam o uso de *deep learning*, inteligência artificial que analisa imagens médicas, para a detecção

de algumas patologias que são mais incidentes no serviço de urgência; pneumotórax, insuficiência cardíaca, pneumonia (bacteriana e por Covid 19) e tuberculose.

Inicialmente, a integração dos resultados obtidos nos três estudos — (Katzman *et al.* 2024), (Sugibayashi *et al.* 2023) e (Hillis *et al.* 2022) — demonstra de forma consistente o alto desempenho dos modelos de aprendizado profundo aplicados à detecção automatizada de pneumotórax em radiografias de tórax, consolidando essa abordagem como uma ferramenta diagnóstica complementar de grande potencial clínico. (Katzman *et al.* 2024), em uma meta-análise com 23 estudos e mais de 34 mil exames, observaram sensibilidade combinada de 87% e especificidade de 95%, indicando que os algoritmos são capazes de identificar casos de pneumotórax com acurácia próxima à dos radiologistas experientes, sem impacto significativo de variáveis como desenho do estudo ou origem do banco de dados. Esses resultados dialogam com os achados de (Sugibayashi *et al.* 2023), que, ao analisar 63 estudos e mais de 30 mil radiografias, também encontraram desempenho semelhante entre modelos de *deep learning* e médicos radiologistas, com AUC médio de 0,97 e sensibilidade e especificidade de 84% e 96%, respectivamente. O estudo europeu ainda destacou que, embora o desempenho dos algoritmos seja robusto, a

Quadro 2 – Artigos usados para a revisão separados por título, autores, ano de publicação, objetivo e a revista em que foram publicados.

| nº | Título Original                                                                                                              | Autores                   | Ano  | Revista                                      |
|----|------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|----------------------------------------------|
| 1  | Deep Learning for Pneumothorax Detection on Chest Radiograph: A Diagnostic Test Accuracy Systematic Review and Meta Analysis | Katzman <i>et al.</i>     | 2024 | Canadian Association of Radiologists Journal |
| 2  | Deep learning for pneumothorax diagnosis: a systematic review and meta-analysis                                              | Sugibayashi <i>et al.</i> | 2023 | European Respiratory Society                 |

|   |                                                                                                                                                                         |                           |      |                                      |
|---|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|--------------------------------------|
| 3 | Evaluation of an Artificial Intelligence Model for Detection of Pneumothorax and Tension Pneumothorax in Chest Radiographs                                              | Hillis <i>et al.</i>      | 2022 | JAMA Network Open                    |
| 4 | Deep learning approach for analyzing chest X-rays to predict cardiac events in heart failure                                                                            | Kusunose <i>et al.</i>    | 2023 | Frontiers in Cardiovascular Medicine |
| 5 | Early Detection of Heart Failure with Autonomous AI-Based Model Using Chest Radiographs: A Multicenter Study                                                            | Garza-frias <i>et al.</i> | 2024 | MDPI                                 |
| 6 | Inteligência Artificial Aplicada à Radiografia de Tórax: Uma Ferramenta Confiável para Avaliar o Diagnóstico Diferencial de Pneumonia Pulmonar no Serviço de Emergência | Ippolito <i>et al.</i>    | 2023 | MDPI                                 |
| 7 | Machine and Deep Learning for Tuberculosis Detection on Chest X-                                                                                                        | Hansun <i>et al.</i>      | 2023 | Journal of Medical Internet Research |

|    |                                                                                                                                                                     |                        |      |                            |
|----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------|------|----------------------------|
|    | Radiographs: Systematic Literature Review                                                                                                                           |                        |      |                            |
| 8  | Chest X-ray Analysis With Deep Learning-Based Software as a Triage Test for Pulmonary Tuberculosis: An Individual Patient Data Meta-Analysis of Diagnostic Accuracy | Tavaziva <i>et al.</i> | 2022 | Oxford Academic            |
| 9  | Weakly-supervised localization of radiographic manifestations in pulmonary tuberculosis from chest X-rays: a systematic review                                      | Feyisa <i>et al.</i>   | 2023 | MDPI                       |
| 10 | A Systematic Review of Deep Learning Techniques for Tuberculosis Detection From Chest Radiograph                                                                    | Oloko-oba; Viriri      | 2022 | Frontiers in Public Health |
| 11 | An artificial intelligence deep learning platform achieves high diagnostic accuracy for Covid-19 pneumonia                                                          | Li, D; Li, S           | 2022 | iScience                   |

|    |                                                                                                                                  |                       |      |                    |
|----|----------------------------------------------------------------------------------------------------------------------------------|-----------------------|------|--------------------|
|    | by reading chest X-ray images                                                                                                    |                       |      |                    |
| 12 | Artificial intelligence-assisted chest X-ray for the diagnosis of COVID-19: a systematic review and meta-analysis                | Tzeng <i>et al.</i>   | 2023 | MDPI               |
| 13 | Development and prospective validation of the COVID-19 chest X-ray triage model for patients presenting to emergency departments | Drozdov <i>et al.</i> | 2021 | Scientific Reports |

Fonte: Desenvolvido pelos autores, 2025

Quadro 3 – Resultados dos estudos sobre o desempenho de algoritmos de aprendizado profundo em radiografias de tórax

| nº | Autor/Ano                        | Amostra                                   | Objetivo                                                                                                  | Principais Resultados Numéricos (Quando apresentado)                                                  | Conclusões Principais                                     |
|----|----------------------------------|-------------------------------------------|-----------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------|-----------------------------------------------------------|
| 1  | Katzman <i>et al.</i> (2024)     | Meta-análise de estudos sobre pneumotórax | Avaliar a precisão de algoritmos de deep learning para detecção de pneumotórax em radiografias torácicas. | Sensibilidade 87% (IC 95%: 81–92%); Especificidade 95% (IC 95%: 92–97%); AUC 0,97 (IC 95%: 0,95–0,98) | DL apresentou desempenho excelente e baixo risco de viés. |
| 2  | Sugibayashi <i>et al.</i> (2023) | 32 estudos (diversas                      | Revisar o desempenho                                                                                      | Sens. 84% (IC 95%: 79–                                                                                | Desempenho comparável a                                   |

|   |                                  |                                                         |                                                                                                              |                                                                                  |                                                                  |
|---|----------------------------------|---------------------------------------------------------|--------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------|------------------------------------------------------------------|
|   |                                  | modalidades)                                            | diagnóstico de modelos de aprendizado profundo aplicados à detecção de pneumotórax.                          | 89%); Esp. 96% (IC 95%: 94–98%); AUC 0,97                                        | especialistas; 57% com alto risco de viés.                       |
| 3 | Hillis <i>et al.</i> (2022)      | 985 radiografias; idade média 60,8 anos; 44,3% mulheres | Validar o desempenho de IA na detecção de pneumotórax e pneumotórax hipertensivo.                            | AUC 0,979; sens. 94,3%; esp. 92,0%; hipertensivo: AUC 0,987                      | IA com alta acurácia, especialmente em pneumotórax hipertensivo. |
| 4 | Kusunose <i>et al.</i> (2023)    | Pacientes com insuficiência cardíaca                    | Aplicar deep learning em radiografias para prever eventos cardíacos em pacientes com insuficiência cardíaca. | AUC = 0,80; sensibilidade = 0,77; especificidade = 0,74; acurácia preditiva alta | IA identificou padrões de remodelamento e congestão pulmonar.    |
| 5 | Garza-frias <i>et al.</i> (2024) | 1.117 radiografias; 630 mulheres; 487 homens            | Desenvolver e validar modelo autônomo baseado em IA para diagnóstico precoce de insuficiência cardíaca.      | AUC 0,798; Sens. 0,813; Esp. 0,684; Acurácia 0,732                               | Modelo robusto entre sexos e grupos de fração de ejeção.         |
| 6 | Ippolito <i>et al.</i> (2023)    | 2.140 COVID-19; 1.500 pneumonia                         | Analisar o uso de IA em radiografias de tórax para diagnóstico diferencial de pneumonia                      | COVID-19: sens. 94,7%, esp. 80,2%; Pneumonia: sens. 97,5%, esp. 83,9%            | IA com concordância quase perfeita ( $\kappa = 0,822–0,913$ ).   |
| 7 | Hansun <i>et al.</i> (2023)      | Revisão sistemática                                     | Revisar técnicas de machine learning e                                                                       | Acurácia 0,83–0,99; Sens. 0,78–0,97; Esp.                                        | Modelos VGG-16, ResNet e DenseNet                                |

|    |                               |                                                  |                                                                                                                                                                                                                               |                                                                  |                                                                                                                     |
|----|-------------------------------|--------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------|
|    |                               |                                                  | deep learning na detecção de tuberculose pulmonar.                                                                                                                                                                            | 0,80–0,98                                                        | com alta robustez diagnóstica.                                                                                      |
| 8  | Tavaziva <i>et al.</i> (2022) | 3.727 participantes; 17% PVHA; 17% TB confirmada | Avaliar softwares de deep learning para triagem de tuberculose em radiografias de tórax.                                                                                                                                      | Sens. 90%; Esp. CAD4TBv6 56,9%; Lunit 54,1%; qXRv2 60,5%         | IA com desempenho semelhante ao de leitores humanos.                                                                |
| 9  | Feyisa <i>et al.</i> (2023)   | Revisão sistemática de estudos sobre TB pulmonar | Compreender como os algoritmos de deep learning podem melhorar a localização e a interpretação automatizada de achados radiográficos em TBP, contribuindo para diagnósticos mais precisos e para o suporte à decisão clínica. | Acurácia média dos modelos acima de 90% em detecção de TB em CXR | DL mostrou alto potencial para identificar padrões sutis e melhorar a explicabilidade e na detecção de TB pulmonar. |
| 10 | Oloko-oba; Viriri (2022)      | 62 estudos incluídos em revisão sistemática      | Revisar sistematicamente as técnicas de deep learning utilizadas na detecção da tuberculose pulmonar em radiografias de tórax, avaliando seu desempenho, bases de                                                             | Acurácia variando de 85% a 98%, AUC até 0,99                     | DL apresentou resultados promissores, mas há necessidade de padronização e validação externa dos modelos.           |

|    |                              |                                                       |                                                                                                                                                                                                                                                                          |                                                                                    |                                                                                                              |
|----|------------------------------|-------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------|
|    |                              |                                                       | dados empregadas e limitações atuais dos estudos.                                                                                                                                                                                                                        |                                                                                    |                                                                                                              |
| 11 | Li, D; Li, S (2022)          | 13.000 radiografias (COVID-19, pneumonia e saudáveis) | Desenvolver e validar uma plataforma de inteligência artificial baseada em deep learning capaz de diagnosticar pneumonia por Covid-19 em radiografias de tórax com alta precisão, distinguindo-a de outras formas de pneumonia viral, bacteriana e de pulmões saudáveis. | Acurácia = 97,4%; sensibilidade = 96,3%; especificidad e = 98,1%                   | IA diferenciou COVID-19 de outras pneumonias com alta precisão e desempenho comparável ao de radiologistas.  |
| 12 | Tzeng <i>et al.</i> (2023)   | Meta-análise de estudos com IA aplicada à COVID-19    | Avaliar a precisão diagnóstica de IA na detecção de COVID-19 em radiografias de tórax por meio de revisão sistemática e meta-análise.                                                                                                                                    | Sensibilidade combinada: 94% (IC95%: 90–96%); especificidad e: 93% (IC95%: 89–95%) | IA demonstrou alta acurácia diagnóstica, reforçando seu uso como ferramenta auxiliar no rastreo de COVID-19. |
| 13 | Drozдов <i>et al.</i> (2021) | 1.500 radiografias de pacientes de emergência         | Desenvolver e validar o modelo Covlx para detectar pneumonia por COVID-19 em                                                                                                                                                                                             | AUC = 0,95; sensibilidade = 0,89; especificidad e = 0,91                           | Modelo Covlx apresentou desempenho comparável a radiologistas na triagem automatizada de                     |



|  |  |  |                                                                   |  |                         |
|--|--|--|-------------------------------------------------------------------|--|-------------------------|
|  |  |  | radiografias de tórax com desempenho similar ao de radiologistas. |  | pneumonia por COVID-19. |
|--|--|--|-------------------------------------------------------------------|--|-------------------------|

Fonte : Desenvolvido pelos autores, 2025

### 3 DISCUSSÃO

Este estudo procura analisar diferentes fontes de dados que discutam o uso de *deep learning*, inteligência artificial que analisa imagens médicas, para a detecção de algumas patologias que são mais incidentes no serviço de urgência; pneumotórax, insuficiência cardíaca, pneumonia (bacteriana e por Covid 19) e tuberculose.

Inicialmente, a integração dos resultados obtidos nos três estudos — (Katzman *et al.* 2024), (Sugibayashi *et al.* 2023) e (Hillis *et al.* 2022) — demonstra de forma consistente o alto desempenho dos modelos de aprendizado profundo aplicados à detecção automatizada de pneumotórax em radiografias de tórax, consolidando essa abordagem como uma ferramenta diagnóstica complementar de grande potencial clínico. (Katzman *et al.* 2024), em uma meta-análise com 23 estudos e mais de 34 mil exames, observaram sensibilidade combinada de 87% e especificidade de 95%, indicando que os algoritmos são capazes de identificar casos de pneumotórax com acurácia próxima à dos radiologistas experientes, sem impacto significativo de variáveis como desenho do estudo ou origem do banco de dados. Esses resultados dialogam com os achados de (Sugibayashi *et al.* 2023), que, ao analisar 63 estudos e mais de 30 mil radiografias, também encontraram desempenho semelhante entre modelos de *deep learning* e médicos radiologistas, com AUC médio de 0,97 e sensibilidade e especificidade de 84% e 96%, respectivamente. O estudo europeu ainda destacou que, embora o desempenho dos algoritmos seja robusto, a heterogeneidade metodológica e o viés de publicação ainda representam limitações que devem ser abordadas em futuras validações multicêntricas.

Ainda mais, no trabalho de (Hillis *et al.* 2022), complementa a literatura ao avaliar um modelo comercial de inteligência artificial aplicado à detecção de pneumotórax simples e hipertensivo, alcançando AUC de 0,979 para pneumotórax e 0,987 para pneumotórax hipertensivo, com sensibilidades superiores a 94% e especificidades acima de 92%. Esses resultados reforçam que os algoritmos de *deep*

*learning* não apenas atingem desempenho comparável ao de especialistas humanos, mas também oferecem a vantagem da triagem rápida de casos críticos, otimizando o fluxo de trabalho radiológico e contribuindo para a priorização de atendimentos emergenciais. Considerando o conjunto das evidências, observa-se uma convergência entre os três estudos no sentido de que o aprendizado profundo representa uma tecnologia promissora e clinicamente aplicável para detecção de pneumotórax. Entretanto, todos os autores ressaltam a necessidade de padronização dos protocolos de treinamento e validação, além de maior transparência nos dados utilizados, a fim de garantir a reprodutibilidade, a segurança diagnóstica e a confiabilidade desses sistemas antes de sua incorporação definitiva na prática clínica.

Em seguida, a análise conjunta dos estudos de (Kuzunose *et al.* 2023) e (Garza-frias *et al.* 2024) demonstra a crescente aplicabilidade de modelos de aprendizado profundo na predição e detecção precoce de insuficiência cardíaca (IC) a partir de radiografias de tórax, ampliando o papel da inteligência artificial (IA) no suporte diagnóstico cardiovascular. (Kuzunose *et al.* 2023) desenvolveram um modelo baseado em radiografias de tórax para prever a elevação da pressão de oclusão da artéria pulmonar (PAWP), parâmetro hemodinâmico fortemente relacionado à IC. O estudo, que avaliou 192 pacientes hospitalizados, demonstrou que a probabilidade elevada de PAWP predita por IA correlacionou-se com disfunção diastólica e maior risco de desfechos adversos, como readmissão e morte cardíaca, independentemente de marcadores ecocardiográficos e laboratoriais tradicionais. O modelo apresentou capacidade incremental de previsão, com estatística C de 0,78 após a inclusão do parâmetro de PAWP, superando a avaliação subjetiva de congestão pulmonar por especialistas. Esses achados sugerem que a IA aplicada à radiografia de tórax pode captar padrões sutis de sobrecarga cardíaca não evidentes ao olho humano, aprimorando a estratificação de risco em pacientes com IC.

De forma complementar, (Garza-frias *et al.* 2024) validaram um modelo autônomo de IA multicêntrico (qXR-HF) capaz de identificar pacientes com risco de desenvolver IC até 12 meses antes do diagnóstico clínico. O algoritmo, treinado com mais de quatro milhões de imagens, demonstrou desempenho robusto (AUC 0,798; sensibilidade 0,81; especificidade 0,68) e estabilidade dos resultados em diferentes subgrupos de tempo e fração de ejeção, atingindo AUC de 0,854 nos casos diagnosticados em menos de três meses após a radiografia. Esses resultados reforçam o potencial da IA para detecção oportunista de IC em exames rotineiros,

permitindo intervenções precoces e redução de morbimortalidade associada. A convergência entre os dois estudos evidencia que a IA aplicada às radiografias de tórax transcende a simples classificação diagnóstica, assumindo papel prognóstico e preventivo relevante. Contudo, ambos os autores reconhecem limitações metodológicas e ressaltam a necessidade de validação prospectiva e multicêntrica para assegurar reprodutibilidade e integração segura dessas ferramentas na prática clínica.

Além disso, o estudo de (Ipollito *et al.* 2023) destaca a eficácia de um sistema de IA baseado em *Mask R-CNN* aplicado à radiografia de tórax em ambiente de emergência, atingindo acurácia global de 93,8% na diferenciação entre COVID-19, pneumonia bacteriana e pulmões saudáveis. Os autores ressaltam que a ferramenta apresentou desempenho semelhante ao de radiologistas experientes, demonstrando concordância quase perfeita ( $\kappa = 0,822$  para COVID-19 e  $\kappa = 0,913$  para pneumonia bacteriana). Esses resultados reforçam o potencial da IA em auxiliar o diagnóstico diferencial rápido, especialmente em contextos de sobrecarga hospitalar.

De modo convergente, (Drozdov *et al.* 2021) desenvolveram o modelo *CovIx*, treinado com mais de 293 mil radiografias, validado prospectivamente em mais de 3 mil imagens de pacientes atendidos em departamentos de emergência. O modelo obteve uma área sob a curva ROC (AUC) de 0,86 para COVID-19, com desempenho comparável ao de radiologistas certificados. Os autores também destacam a importância da padronização e qualidade das imagens, apontando que modelos treinados em bases heterogêneas ou mal anotadas tendem a superestimar seu desempenho, o que prejudica a generalização dos resultados — um ponto crítico na aplicação clínica da IA.

Sob uma perspectiva de síntese, a meta-análise de (Tzeng *et al.* 2023) oferece uma visão abrangente ao reunir nove estudos com 39.603 participantes, confirmando a elevada acurácia da IA assistida em radiografias de tórax para detecção de COVID-19. A análise combinada indicou sensibilidade média de 94,7% e especificidade de 96,1%, com área sob a curva de 0,98. Esses achados consolidam a IA como ferramenta diagnóstica robusta, capaz de complementar testes laboratoriais e exames mais complexos, como a tomografia computadorizada, sobretudo em locais com recursos limitados.

Ainda mais expressivos são os resultados apresentados por (Li, D; Li, S 2022), que propuseram uma plataforma de aprendizado profundo combinando 17 redes

neurais convolucionais (CNNs) por meio de um algoritmo de votação. Essa arquitetura atingiu taxas de acerto superiores a 99% na distinção entre COVID-19, pneumonia bacteriana e casos saudáveis. Embora o desempenho seja impressionante, os autores reconhecem que o elevado grau de controle sobre as bases de dados utilizadas pode limitar a aplicabilidade direta dos modelos a ambientes clínicos reais, nos quais há grande variabilidade na qualidade das imagens e nas condições de captura.

Ao comparar os quatro estudos, evidencia-se um consenso quanto à relevância clínica da IA na radiologia torácica, embora com diferentes graus de maturidade tecnológica. Enquanto (Ipollito *et al.* 2023) e (Drozdov *et al.* 2021) enfatizam a validação em cenários reais de pronto atendimento, (Tzeng *et al.* 2023) e (Li, D; Li, S 2022) abordam a dimensão estatística e o potencial máximo dos modelos em condições controladas. Dessa forma, constata-se que a IA é promissora não apenas para o diagnóstico, mas também como suporte à tomada de decisão clínica, reduzindo o tempo de triagem e permitindo uma gestão mais eficiente de recursos humanos e hospitalares.

Além dos estudos previamente mencionados, outras pesquisas recentes reforçam a importância do uso de técnicas de aprendizado profundo (*Deep Learning*) e aprendizado de máquina (*Machine Learning*) na detecção da tuberculose (TB) a partir de radiografias de tórax (*Chest X-Ray* – CXR). De acordo com (Oloko-oba; Viriri, 2022), o desenvolvimento de sistemas de diagnóstico auxiliado por computador (Computer-Aided Diagnosis – CAD) tem representado um avanço significativo em regiões de alta carga da doença, nas quais há escassez de profissionais especializados para interpretar imagens radiográficas. Os autores salientam que as redes neurais convolucionais (*Convolutional Neural Networks* – CNNs) têm demonstrado elevado desempenho na identificação de anormalidades pulmonares, reduzindo o tempo de análise e aumentando a precisão diagnóstica, fatores que contribuem diretamente para a meta da Organização Mundial da Saúde de erradicar a tuberculose até 2035.

Complementarmente, (Hansun *et al.* 2023) observaram que os modelos baseados em *Deep Learning* superam, em muitos casos, os métodos tradicionais de *Machine Learning*, principalmente no que se refere à área sob a curva (AUC) e à especificidade. Por outro lado, os modelos de ML apresentaram maior sensibilidade média, o que sugere que ambas as abordagens podem ser complementares,

dependendo do contexto clínico e da disponibilidade de dados. Os autores identificaram ainda que as arquiteturas ResNet-50, VGG-16, VGG-19 e AlexNet são as mais utilizadas nas pesquisas atuais, devido à sua capacidade de generalização e eficiência computacional. No entanto, ressaltam a existência de heterogeneidade metodológica e risco de viés nos estudos, especialmente quanto ao padrão de referência e à seleção amostral, o que limita a comparabilidade e a reprodutibilidade dos resultados.

Nesse mesmo eixo temático, (Feyisa *et al.* 2023) destacam o papel das técnicas de localização e segmentação fraca (*weak localization*), que se mostram alternativas promissoras frente às dificuldades de anotação detalhada de imagens médicas. Conforme os autores, a rotulagem manual e pixel a pixel por especialistas demanda tempo e custos elevados, além de envolver subjetividade interpretativa. Assim, os métodos de aprendizado fraco e semi-supervisionado possibilitam a identificação das regiões mais relevantes da imagem sem a necessidade de anotações extensivas, tornando o processo mais acessível e adaptável a contextos com recursos limitados.

Por outro lado, (Tavaziva *et al.* 2022) abordaram o desempenho de softwares comerciais de análise radiográfica automatizada, como CAD4TBv6, Lunit e qXRv2, em uma meta-análise de dados individuais. Os resultados indicaram que, embora a acurácia global dos modelos de DL seja semelhante à de leitores humanos, há variações significativas conforme o perfil populacional, especialmente entre pacientes com HIV e aqueles com baciloscopia negativa. Dessa forma, os autores defendem que a calibração dos limiares de decisão deve considerar as características epidemiológicas e clínicas da população atendida, evitando interpretações equivocadas e garantindo maior eficiência diagnóstica.

Diante desse conjunto de evidências, observa-se uma convergência entre os estudos quanto ao potencial transformador da inteligência artificial (IA) no apoio ao diagnóstico da tuberculose. Contudo, persiste a necessidade de padronização dos protocolos de validação, integração entre bases de dados multicêntricas e avaliação ética do uso clínico dessas tecnologias. Além disso, o fortalecimento de abordagens explicáveis (*explainable AI*) e a criação de modelos interpretáveis e transparentes são essenciais para aumentar a confiança dos profissionais de saúde e dos gestores públicos. Assim, o avanço contínuo das técnicas de aprendizado profundo, aliado à integração de informações clínicas e sociodemográficas, tem potencial para aprimorar

a precisão diagnóstica, reduzir desigualdades no acesso à saúde e consolidar o uso seguro da IA no contexto da saúde pública global.

#### 4 CONCLUSÃO

Com base na análise dos estudos revisados, fica evidente que a aplicação da inteligência artificial, especialmente por meio de técnicas de *deep learning*, tem se mostrado uma ferramenta promissora para a análise de radiografias de tórax em ambientes de urgência. A tecnologia tem demonstrado alto desempenho na detecção de patologias críticas, como pneumotórax, insuficiência cardíaca, pneumonia e tuberculose, apresentando resultados equivalentes — e, em alguns casos, superiores — aos obtidos por radiologistas experientes. Além da precisão diagnóstica, destaca-se a capacidade da IA de agilizar o processo de triagem e priorização de casos graves, o que representa um ganho significativo em contextos de alta demanda e limitação de recursos humanos.

Entretanto, mesmo diante dos avanços, ainda existem desafios a serem superados, principalmente no que diz respeito à padronização dos protocolos de treinamento, à validação multicêntrica dos modelos e à transparência dos dados utilizados. Esses fatores são fundamentais para garantir a reprodutibilidade e a segurança diagnóstica, evitando que vieses técnicos ou populacionais comprometam os resultados clínicos. Assim, a IA deve ser vista não como uma substituta do olhar médico, mas como uma aliada estratégica que complementa e potencializa a tomada de decisão, especialmente em situações de urgência, onde o tempo e a precisão são determinantes para o prognóstico do paciente.

Em síntese, o uso da inteligência artificial na análise de radiografias de tórax representa um passo importante rumo a uma medicina mais ágil, precisa e acessível. Com investimento contínuo em pesquisa, validação e ética no uso de dados, essa tecnologia tem potencial real para transformar o diagnóstico por imagem em um instrumento ainda mais eficiente a serviço da saúde pública e do cuidado humanizado.

#### REFERÊNCIAS

AGGARWAL, R. et al. Diagnostic accuracy of deep learning in medical imaging: a systematic review and meta-analysis. **NPJ Digital Medicine**, Londres, v. 4, art. 65, 2021. DOI: <https://doi.org/10.1038/s41746-021-00438-z>. Disponível em: <https://doi.org/10.1038/s41746-021-00438-z>. Acesso em: 28 ago. 2025.

BRASIL. Ministério da Saúde. Protocolo Clínico e Diretrizes Terapêuticas – Tuberculose. Brasília: Ministério da Saúde, 2022. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/t/tuberculose>. Acesso em: 28 ago. 2025.

DROZDOV, I. et al. Development and prospective validation of COVID-19 chest X-ray screening model for patients attending emergency departments. **Scientific Reports**, Londres, v. 11, n. 20384, 2021. DOI: <https://doi.org/10.1038/s41598-021-99986-3>. Disponível em: <https://doi.org/10.1038/s41598-021-99986-3>. Acesso em: 30 set. 2025.

FEYISA, D. W. et al. Weak localization of radiographic manifestations in pulmonary tuberculosis from chest X-ray: a systematic review. **Sensors, Basel**, v. 23, n. 6781, p. 1–31, 2023. DOI: <https://doi.org/10.3390/s23076781>. Disponível em: <https://doi.org/10.3390/s23076781>. Acesso em: 30 set. 2025.

FLEISCHNER SOCIETY. Glossary of terms for thoracic imaging. Radiology, Chicago, v.296,n.3,p.697–722,2020.DOI: <https://doi.org/10.1148/radiol.2020202520>. Disponível em: <https://doi.org/10.1148/radiol.2020202520>. Acesso em: 30 set. 2025.

GARZA-FRIAS, E. et al. Early detection of heart failure with autonomous AI-based model using chest radiographs: a multicenter study. **Diagnostics, Basel**, v. 14, n. 16, p.1635,2024.DOI: <https://doi.org/10.3390/diagnostics14151635>. Disponível em: <https://doi.org/10.3390/diagnostics14151635>. Acesso em: 30 set. 2025.

GONÇALVES, F. L. et al. Utilização de ferramentas de Inteligência Artificial (IA) no diagnóstico de imagem. **Research, Society and Development**, São Paulo, v. 13, n. 11, e64131147312, 2024. DOI: <https://doi.org/10.33448/rsd-v13i11.47312>. Disponível em: <https://doi.org/10.33448/rsd-v13i11.47312>. Acesso em: 28 ago. 2025.

HANSUN, S. et al. Machine and deep learning for tuberculosis detection on chest X-rays: systematic literature review. **Journal of Medical Internet Research**, Toronto, v. 25, 43154, 2023. DOI: <https://doi.org/10.2196/43154>. Disponível em: <https://doi.org/10.2196/43154>. Acesso em: 30 set. 2025.

HILLIS, J. M. et al. Evaluation of an artificial intelligence model for detection of pneumothorax and tension pneumothorax in chest radiographs. **JAMA Network Open**, Chicago, v. 5, n. 12, e2247172, 2022. DOI: <https://doi.org/10.1001/jamanetworkopen.2022.47172>. Disponível em: <https://doi.org/10.1001/jamanetworkopen.2022.47172>. Acesso em: 30 set. 2025.

IPPOLITO, D. et al. Artificial intelligence applied to chest X-ray: a reliable tool to assess the differential diagnosis of lung pneumonia in the emergency department. **Diseases, Basel**, v. 11, n. 171, 2023.

DOI: <https://doi.org/10.3390/diseases11040171>. Disponível em: <https://doi.org/10.3390/diseases11040171>. Acesso em: 30 set. 2025.

KATZMAN,B.D. et al. Deep learning for pneumothorax detection on chest radiograph: a diagnostic test accuracy systematic review and meta-analysis. **Canadian Association of Radiologists Journal**, Toronto, v. 75, n. 3, p. 525–533, 2024. DOI: <https://doi.org/10.1177/08465371231220885>. Disponível em: <https://doi.org/10.1177/08465371231220885>. Acesso em: 30 set. 2025.

KHALIL,M.A. etal. Chest X-ray interpretation:a systematic approach. **Journal of Thoracic Imaging**, Nova Iorque, v. 34, n. 1, p. 54–65, 2019. DOI: <https://doi.org/10.1097/RTI.0000000000000385>. Disponível em: <https://doi.org/10.1097/RTI.0000000000000385>. Acesso em: 28 ago. 2025

KUSUNOSE, K. et al. Deep learning approach for analyzing chest X-rays to predict cardiac events in heart failure. **Frontiers in Cardiovascular Medicine**, Lausanne, v. 10, p. 1081628, 2023. DOI: <https://doi.org/10.3389/fcvm.2023.1081628>. Disponível em: <https://doi.org/10.3389/fcvm.2023.1081628>. Acesso em: 30 set. 2025..

LI,D.;LI,S. An artificial intelligence deep learning platform achieves high diagnostic accuracy for Covid-19 pneumonia by reading chest X-ray images. **iScience**, Amsterdã, v. 25, n. 104031, 2022. DOI: <https://doi.org/10.1016/j.isci.2022.104031>. Disponível em: <https://doi.org/10.1016/j.isci.2022.104031>. Acesso em: 30 set. 2025..

MELLO-THOMS,C.;MELLO,C.A.B.Clinical applications of artificial intelligence in radiology. **British Journal of Radiology**, Londres, v. 96, n. 1150, 2023. DOI: <https://doi.org/10.1259/bjr.20221031>. Disponível em: <https://doi.org/10.1259/bjr.20221031>. Acesso em: 28 ago. 2025.

OCAÑA-FERNÁNDEZ, Y.; FUSTER-GUILLÉN, D. A revisão bibliográfica como metodologia de pesquisa. **Revista Tempos e Espaços em Educação**, Sergipe, v. 14, n. 33, p. 1–16, 2021. DOI: <https://doi.org/10.20952/revtee.v14i33.15614>. Disponível em: <https://doi.org/10.20952/revtee.v14i33.15614>. Acesso em: 28 ago. 2025.

OLOKO-OBA,M.;VIRIRI,S.A systematic review of deep learning techniques for tuberculosis detection from chest radiograph. **Frontiers in Medicine**, Lausanne, v. 9, n. 830515, p. 1–15, 2022. DOI: <https://doi.org/10.3389/fmed.2022.830515>. Disponível em: <https://doi.org/10.3389/fmed.2022.830515>. Acesso em: 30 set. 2025.

SILVA, R. A.; SOUZA, L. P. Radiografia de tórax: princípios, indicações e interpretação. **Revista Brasileira de Radiologia Médica**, São Paulo, v. 4, n. 2, p. 45–52,2021.Disponívelem: <https://revistas.ufg.br/rbrm/article/view/14252> . Acesso em: 28 ago. 2025.



SUGIBAYASHI, T. et al. Deep learning for pneumothorax diagnosis: a systematic review and meta-analysis. **European Respiratory Review**, Londres, v. 32, n. 220259, 2023. DOI: <https://doi.org/10.1183/16000617.0259-2022>. Disponível em: <https://doi.org/10.1183/16000617.0259-2022>. Acesso em: 30 set. 2025.

TAVAZIVA, G. et al. Chest X-ray analysis with deep learning-based software as a triage test for pulmonary tuberculosis: an individual patient data meta-analysis of diagnostic accuracy. **Clinical Infectious Diseases**, Oxford, v. 74, n. 8, p. 1390–1400, 2022. DOI: <https://doi.org/10.1093/cid/ciab639>. Disponível em: <https://doi.org/10.1093/cid/ciab639>. Acesso em: 30 set. 2025.

TZENG, I.-S. et al. Artificial intelligence-assisted chest X-ray for the diagnosis of COVID-19: a systematic review and meta-analysis. **Diagnostics**, Basel, v. 13, n. 584, 2023. DOI: <https://doi.org/10.3390/diagnostics13040584>. Disponível em: <https://doi.org/10.3390/diagnostics13040584>. Acesso em: 30 set. 2025.

VAROQUAUX, G.; CHEPLYGINA, V. Machine learning for medical imaging: methodological failures and recommendations for the future. **NPJ Digital Medicine**, Londres, v. 5, art. 48, 2022. DOI: <https://doi.org/10.1038/s41746-022-00592-y>. Disponível em: <https://doi.org/10.1038/s41746-022-00592-y>. Acesso em: 28 ago. 2025.